

時空間グラフ構造を考慮した深層学習にもとづく都市発生人数予測の検討 Prediction of the outflow number in each city based on a deep learning model with spatio-temporal graph structures.

北野 佑[†]

Yu Kitano

鎌本 賢志[†]

Satoshi Kuwamoto

1. はじめに

近年、世界的に都市化が急速に進んでおり、2050 年までに都市の人口が全人口の 70% 近くを占めると見込まれている[1]。このような人口集中により、交通混雑や公共サービスの不足等様々な問題が発生し、人々の QoL 低下を招くことになる。こうした状況に応じて、スマートシティの実現へ注目が集まっている。特に最近では、COVID-19 の流行を受け、都市の強靭性が一層問題視される状況にある。

人口集中や混雑に関わる問題において、人の流れの予測、制御は重要な要素の一つである。そのため、都市における人の動きに関するデータ(動線データ)の分析・利活用が近年注目されている。動線データを分析、予測することにより、都市の交通や移動に関する施策を策定することが可能となる。例えば交通の渋滞緩和や、移動手段の最適化、公共交通機関の運行改善などに応用することができ、動線データ分析技術をコアとするサービスやソリューションが求められている。

本研究では、都市の交通や移動に関する施策策定のため、GPS データを活用した地域ごとの発生人数予測を行う技術を検討する。集積された GPS データに対して滞留判定にもとづく OD(Origin-Destination)分析を行い、地域ごとの発生人数を算出したうえで、発生人数の時空間的な関係性を考慮したグラフ構造にもとづく深層学習モデルにより、過去の発生人数より将来の発生人数を予測する手法を検討した。上記アプローチにより、発生人数予測を行った結果について報告する。

2. 提案手法

2.1 OD 分析による発生人数算出

本研究では GPS 測位にて取得された動線データを扱う。ここでいう動線データとは、人の識別子、時刻、位置(緯度・経度)座標から構成されるデータのことであり、人が移動する際、何種類かの目的地に立ち寄ってから最終的な目的地に向かうことが多い。そのため、動線データに対して滞留判定にもとづく OD 分析を行うことでトリップ単位の動線に分割し、地域ごとの位置、形状を示すジオメトリデータと交差判定を行うことで、地域ごとの発生人数を算出する。ここでいうトリップ単位とは途中の目的地間の移動単位のことであり、本研究では以下の手順に従って OD 分析を行い、発生人数を算出する。

滞留判定: 人は目的地到着時にその場で滞留すると仮定し、まず動線データに対して滞留判定を行う。各時刻における動線データに対して、過去 P 分間における平均速度を算出し、その平均速度が V [m/s] より小さいときに滞留とみなす。

[†] (株)日立製作所 研究開発グループ

Hitachi Ltd., Research and Development Group

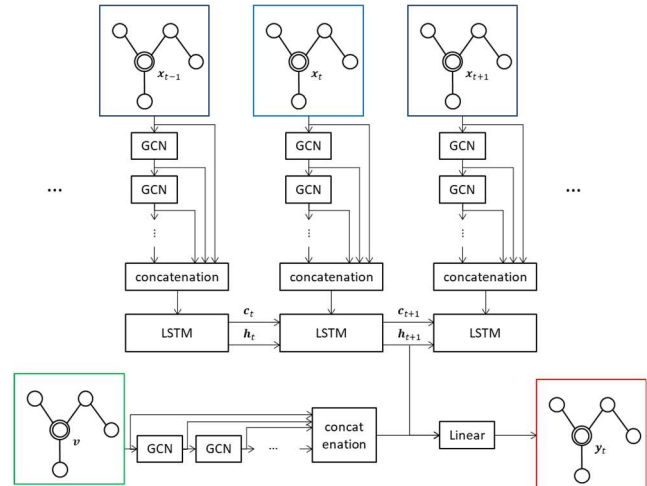


図 1 発生人数予測モデルのネットワーク構造

トリップ分割: 滞留後に再度移動した際は、新しい目的地へ移動を開始したとみなし、滞留のタイミングで動線データを分割する。具体的には滞留状態が T_s 分以上続いた際、動線データをトリップ別に分割する。なお計測の特性上、一定期間位置情報が取得されない場合もあるため、 T_l 分以上位置情報が記録されていない際も、目的地に到着したと判定して、動線データを分割する。

OD 分析: トリップごとの動線データに対して、地域単位を示すジオメトリデータとの交差判定を行い、各トリップの始点(Origin)と終点(Destination)がどの地域に属するかを分析する。

発生人数算出: OD 情報が付加されたトリップごとの動線データを、時間、始点情報にもとづきカウントすることで、各時刻における発生人数とする。

2.2 発生人数予測モデル

前節にて算出した発生人数のデータを用いて、過去の発生人数より将来の発生人数を予測するモデルを学習する。発生人数は時空間的な関係性があるため、これを LSTM (Long Short Term Memory) と GCN(Graph Convolutional Network)の組み合わせにより表現し予測する。また発生人数以外のデータとして各地域の特徴を表す外部データを活用することで予測精度の向上を狙う。本研究で提案するネットワーク構造を図 1 に示す。GCN の適用にはグラフを定義する必要があるが、本研究では各地域の特徴量をノード、地域間の関係をエッジとすることでグラフを定義する。ノード特徴量 $x_t \in \mathbb{R}^{1 \times N}$ を各地域の発生人数とし、多段に GCN を適用し、各 GCN 出力結果を元のノード特徴量 x_t に結合していくことで、時系列特徴量を生成する。ここで N はノード数、 t は時間を示す。同様に外部データ v についても同様に多段に GCN を適用し、各 GCN 出力結果を v に結

合することで外部特徴量を生成する。なお GCN を適用する回数はそれぞれ n_x, n_v とする。その後、生成された時系列特徴量を LSTM に入力し、LSTM の出力と外部特徴量の線形結合により、予測値 $\mathbf{y}_t \equiv (\hat{\mathbf{x}}_{t+1}, \dots, \hat{\mathbf{x}}_{t+R})^T \in \mathbb{R}^{R \times N}$ を出力する。ここで R は予測する時間幅を示す。

3. 実験

3.1 利用データ

提案方式の有効性を検証するために、発生人数予測の評価実験を行った。本研究では、動線データとして株式会社 Agoop にて販売されている流動人口データを用いた[2]。本データはスマホアプリから取得された GPS 位置情報であり、ID に関する情報を秘匿化したデータである。国内の東京都内、神奈川県内、札幌市内に関する 3 都市の動線データであり、詳細について表 1 に示す。動線データから地域ごとの発生人数を算出するために、上記 3 都市に関する地域ごとのジオメトリデータとして、国土数値情報の行政区画データを利用した[3]。本データは全国の行政区画について、都道府県名、支庁・振興局名、郡・政令都市名、市区町村名、行政区画コード等を GIS データとして整備したものである。地域単位として、本研究では市区町村ごとの単位で発生人数を算出した。また各地域の特徴を表す外部データとして、国土数値情報の人口、道の駅、バス停留所、空港、鉄道に関するデータを利用した[3]。人口に関しては、市区町村ごとの全人口、15 歳未満、15-64 歳、65 歳以上の人口を、道の駅、バス停留所、空港、鉄道に関しては、各市区町村内に含まれるジオメトリデータの数をそれぞれカウントしたものを、外部特徴量 \mathbf{v} として予測に用いた。

表 1 データセット詳細

Data Profile	Tokyo	Kanagawa	Sapporo
Mesurement date	October. 1 st -31 st in 2019		
# of IDs	5,958,530	2,803,747	672,465
# of records	518,809,174	250,749,865	42,607,915
# of regions	62	58	10

3.2 実験条件

本研究では、各都市のデータセットに対し、OD 分析を行うことで 1 時間ごとの発生人数を算出した。OD 分析のパラメータは、 $P = 60, V = 0.5, T_s = 1, T_l = 60$ とした。OD 分析により算出された発生人数と先述の外部データを用いて予測モデルを学習した。過去 5 時間分の発生人数と外部特徴量を入力として、将来 5 時間分の発生人数を予測するモデルを学習した。本研究におけるグラフ構造はノードの全結合とし、エッジ特徴量は各ノード間の距離の逆数とした。学習に用いた発生人数データは 2019 年 10 月 1 日から 24 日に計測されたデータとし、評価には 2019 年 10 月 25 日から 31 日までに計測されたデータと用いた。精度評価の尺度としては、正解値の平均値に対する平均絶対誤差の割合(MAER: Mean Absolute Error Ratio)を算出した。本指標にて将来 5 時間分の予測値全ての誤差、また 1 時間ごとの予測誤差を評価した。従来手法として、LSTM、GCN、GraphConvLSTM、LSTM GCN との精度比較を行った。LSTM GCN は各ノードについて LSTM を適用した後、




図 2 精度比較結果

GCN を適用して予測するモデルである。予測実験を行う際に、各都市ごとに予測モデルを学習し、予測、精度評価、比較を行った。

3.3 実験結果

MAER 精度比較結果を図 2 に示す。提案手法は LSTM よりも、誤差が約 10%改善していることが分かる(MAER : 0.312→0.275)。各時間ごとに見ると、1 時間後の予測結果については、提案手法と LSTM で精度がほぼ同等となっているが、5 時間後の予測結果については提案手法の方が高精度な結果となっており、提案手法の方が長期予測に適した手法であることが分かる。GCN については全体的に精度が悪い結果となった。GCN はグラフ構造に従い特徴量の畳み込みを行うが、その影響で特徴量が平滑化される傾向があり、モデルの表現能力が落ちたと考えられる。GraphConvLSTM や LSTM GCN に関しても同様に特徴量が平滑化されてしまい、精度が悪化したと思われる。それに比べて提案手法は、GCN 特徴量を元の特徴量に結合することで情報の損失を防ぎつつ、他の地域の変動を予測に用いることができるため、高精度に予測できたと考えられる。

4. おわりに

都市の交通や移動に関する施策策定において、人流予測は重要な要素の一つである。本研究では、動線データを活用した地域ごとの発生人数予測の技術を検討した。動線データに対して滞留判定にもとづく OD 分析を行い、地域ごとの発生人数を算出したうえで、発生人数の時空間的な関係性を考慮したグラフ構造にもとづく深層学習モデルを用いた発生人数の予測手法を提案した。東京都、神奈川県、札幌市の 3 都市にて GPS 測位された動線データを用いて、市町村単位の発生人数を算出し、過去 5 時間分の発生人数より将来 5 時間分の発生人数を予測する評価実験を行ったところ、既存手法である LSTM より平均絶対誤差割合が約 10%が改善することを確認した。今後の課題は都市転移タスクに関する予測精度向上である。

参考文献

- [1] 国際連合広報センター. 人口構成の変化.
https://www.un.org/activities/international_observances/un75/issue-briefs/shifting-demographics/.
- [2] 株式会社 Agoop. 流動人口データ.
<https://www.agoop.co.jp/service/dynamic-population-data/>.
- [3] 国土数値情報. 国土数値情報ダウンロードサービス.
<https://nlftp.mlit.go.jp/ksj/index.html>.